

BAB I

PENDAHULUAN

1.1 Latar Belakang

Stroke merupakan salah satu penyakit tidak menular yang menjadi penyebab utama kematian dan kecacatan jangka panjang di dunia. Hal ini menjadi perhatian serius mengingat stroke tidak memandang usia dan dapat menyerang kelompok usia dewasa maupun lansia. Dampak stroke tidak hanya dirasakan pada aspek kesehatan individu, tetapi juga menimbulkan beban sosial dan ekonomi yang besar akibat meningkatnya kebutuhan perawatan jangka panjang serta menurunnya produktivitas penderita. Berbagai faktor risiko seperti usia, hipertensi, penyakit jantung, kadar glukosa darah, indeks massa tubuh, serta gaya hidup tidak sehat diketahui berkontribusi terhadap peningkatan risiko terjadinya stroke. Oleh karena itu, upaya skrining awal untuk mengidentifikasi individu yang berisiko tinggi menjadi sangat penting sebagai bagian dari strategi pencegahan dan pengendalian penyakit stroke [1].

Perkembangan teknologi informasi yang pesat dan ketersediaan data kesehatan dalam jumlah besar membuka peluang untuk menerapkan metode machine learning dalam memprediksi risiko stroke secara lebih akurat dan efisien [2]. Model prediksi berbasis data dapat membantu tenaga medis dalam mengidentifikasi individu yang berpotensi mengalami stroke sebelum gejala klinis yang berat muncul, sehingga memungkinkan tindakan pencegahan yang lebih dini dan tepat sasaran. Namun, penerapan machine learning pada data kesehatan menghadapi tantangan utama berupa ketidakseimbangan kelas (class imbalance), di mana jumlah pasien yang benar-benar mengalami stroke jauh lebih sedikit dibandingkan dengan populasi non-stroke [3],[4]. Kondisi ini sering menyebabkan model menghasilkan akurasi yang tinggi tetapi gagal mendeteksi sebagian besar kasus stroke.

Dalam konteks prediksi penyakit, kesalahan yang paling berbahaya dan memiliki implikasi klinis yang serius adalah false negative, yaitu kondisi ketika pasien yang sebenarnya berisiko tinggi atau telah mengalami stroke diklasifikasikan secara keliru sebagai tidak berisiko. Kesalahan ini dapat mengakibatkan keterlambatan intervensi medis dan meningkatkan kemungkinan terjadinya komplikasi serius atau kematian [5]. Sebaliknya, false positive atau kondisi dimana pasien yang sehat atau tidak terkena penyakit di klasifikasikan telah mengalami stroke, meskipun kondisi ini dapat menimbulkan kecemasan dan biaya pemeriksaan tambahan, namun konsekuensi yang diterima jauh lebih ringan karena pemeriksaan lanjutan akan mengklarifikasi status kesehatan yang sebenarnya [6]. Oleh karena itu, sistem prediksi risiko stroke tidak dapat dinilai semata-mata berdasarkan akurasi global, melainkan harus memperhatikan secara khusus kemampuan model dalam mendeteksi sebanyak mungkin kasus stroke yang sebenarnya terjadi, yang secara teknis diukur melalui metrik sensitivitas atau recall, serta meminimalkan jumlah false negative.

Sejumlah penelitian dalam bidang prediksi stroke menggunakan machine learning telah mulai mengarahkan perhatian pada peningkatan sensitivitas model melalui berbagai pendekatan, seperti penanganan ketidakseimbangan data menggunakan teknik oversampling (misalnya SMOTE atau Synthetic Minority Over-sampling Technique), penyesuaian threshold klasifikasi, dan penggunaan fungsi objektif berbasis recall dalam proses optimasi hyperparameter [7],[8],[9]. Meskipun demikian, evaluasi kinerja model dalam penelitian-

penelitian tersebut umumnya masih dilakukan secara parsial dan belum disusun dalam suatu kerangka evaluasi yang sistematis dan komprehensif [10],[11]. Akibatnya, sensitivitas dan jumlah false negative sering kali diperlakukan sebagai indikator tambahan, bukan sebagai kriteria utama dalam proses evaluasi, pemilihan, dan validasi model prediksi.

Berdasarkan hasil penelitian sebelumnya dan hasil pengolahan awal pada penelitian ini, terlihat bahwa model dengan akurasi tinggi belum tentu memiliki kemampuan deteksi stroke yang baik. Model Random Forest pada kondisi baseline (tanpa penanganan ketidakseimbangan kelas), mampu menghasilkan akurasi yang tinggi secara statistik, namun hampir seluruh kasus stroke gagal terdeteksi, yang mengindikasikan bahwa model cenderung memprediksi kelas mayoritas (non-stroke). Sebaliknya, model Decision Tree (CART) yang dioptimasi dengan fokus eksplisit pada recall sebagai fungsi objektif dalam hyperparameter tuning, mampu meningkatkan jumlah kasus stroke yang terdeteksi secara signifikan, meskipun disertai dengan penurunan akurasi global dan peningkatan false positive. Temuan ini menunjukkan bahwa dalam konteks skrining medis, terutama untuk penyakit dengan konsekuensi serius seperti stroke, pendekatan evaluasi model harus disesuaikan dengan tujuan klinis dan prioritas keamanan pasien, bukan semata-mata mengejar performa global yang dapat menyesatkan [12].

Oleh karena itu, diperlukan suatu pendekatan evaluasi komparatif yang secara eksplisit dan sistematis menempatkan sensitivitas dan jumlah false negative sebagai kriteria utama dalam menilai kinerja model prediksi risiko stroke [13],[14]. Penelitian ini berfokus pada evaluasi dan perbandingan kinerja dua algoritma klasifikasi yang populer dan sering digunakan, yaitu Decision Tree (CART atau Classification and Regression Trees) dan Random Forest, dalam memprediksi risiko stroke pada dataset dengan ketidakseimbangan kelas yang tinggi [15]. Evaluasi dilakukan dengan penekanan pada sensitivitas sebagai metrik utama, dilengkapi dengan analisis threshold optimization untuk meminimalkan false negative, serta risk stratification untuk memberikan rekomendasi praktis dalam implementasi sistem skrining [16]. Untuk memastikan robustness dan generalisasi hasil, validasi model dilakukan menggunakan Repeated Stratified K-Fold Cross-Validation yang memberikan estimasi kinerja yang lebih stabil dan dapat diandalkan. Hasil evaluasi komprehensif ini diharapkan dapat memberikan dasar yang lebih tepat dalam pemilihan model yang paling sesuai, aman, dan efektif untuk digunakan sebagai alat skrining awal risiko stroke dalam praktik klinis [17].

1.2 Identifikasi Masalah

Berdasarkan latar belakang yang telah diuraikan, beberapa permasalahan utama dalam penelitian ini dapat diidentifikasi sebagai berikut:

1. Data prediksi stroke memiliki distribusi kelas yang tidak seimbang, di mana jumlah pasien stroke jauh lebih sedikit dibandingkan kasus non-stroke yang menyebabkan model cenderung bias terhadap kelas mayoritas.
2. Model machine learning dengan nilai akurasi yang tinggi belum tentu mampu mendeteksi kasus stroke dengan baik.
3. Tingginya jumlah false negative berpotensi menyebabkan kegagalan dalam melakukan deteksi dini terhadap individu berisiko tinggi.

4. Belum adanya kerangka evaluasi yang secara eksplisit memprioritaskan sensitivitas dan false negative dalam pemilihan model prediksi risiko stroke.

1.3 Rumusan Masalah

Berdasarkan identifikasi masalah tersebut, maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana kinerja algoritma Decision Tree (CART) dan Random Forest dalam memprediksi risiko stroke pada data yang tidak seimbang?
2. Bagaimana penerapan teknik penanganan ketidakseimbangan kelas serta optimasi model berbasis recall memengaruhi kemampuan deteksi kasus stroke?
3. Model manakah yang paling layak digunakan sebagai sistem skrining awal risiko stroke berdasarkan sensitivitas dan tingkat kesalahan false negative?

1.4 Tujuan Penelitian

1. Menganalisis dan membandingkan kinerja model Decision Tree (CART) dan Random Forest dalam memprediksi risiko stroke pada dataset yang tidak seimbang, dengan fokus pada sensitivitas dan jumlah false negative sebagai metrik evaluasi utama.
2. Mengevaluasi pengaruh penerapan teknik SMOTE dan optimasi parameter berbasis recall terhadap peningkatan sensitivitas dan kemampuan deteksi stroke.
3. Mengembangkan dan menerapkan framework evaluasi berbasis sensitivitas dengan validasi menggunakan Repeated Stratified K-Fold Cross-Validation untuk menilai robustness dan stabilitas kinerja model prediksi risiko stroke.
4. Melakukan analisis threshold optimization untuk meminimalkan false negative, serta melakukan risk stratification untuk memberikan rekomendasi praktis dalam implementasi sistem skrining.
5. Melakukan analisis error profiling terhadap karakteristik kasus false negative dan feature importance analysis untuk memahami faktor-faktor risiko yang paling berpengaruh dan penyebab kegagalan deteksi.
6. Menentukan model yang paling sesuai dan aman untuk digunakan sebagai alat skrining awal risiko stroke berdasarkan evaluasi komprehensif terhadap sensitivitas, jumlah false negative.

1.5 Manfaat Penelitian

1. Manfaat Akademis : Memberikan kontribusi dalam pengembangan kajian machine learning pada bidang kesehatan, khususnya dalam evaluasi model prediksi pada data yang tidak seimbang.
2. Manfaat Praktis : Memberikan dasar bagi pengembangan sistem skrining risiko stroke yang lebih sensitif dalam mendeteksi individu berisiko tinggi.
3. Manfaat bagi Pengambil Keputusan : Menyediakan kerangka evaluasi yang membantu tenaga medis dan pengembang sistem informasi kesehatan dalam memilih model prediksi yang lebih aman dan sesuai untuk aplikasi klinis.